

Ivana Rašić Bakarić*

Marina Tkalec**

Maruška Vizek***

UDK 330.33.012(497.5)

JEL Classification C22, C53

Izvorni znanstveni članak

PRIMJENA MODELSKOG PRISTUPA U IZRAČUNU NAVJEŠĆUJUĆEG KOMPOZITNOG INDEKSA: SLUČAJ CROLEI INDEKSA

Cilj članka je unaprijediti postojeću metodologiju CROLEI indeksa te izračunati novi i unaprijeđeni CROLEI indeks čija svrha je naviještanje točaka zaokreta poslovnog ciklusa i kretanja realne ekonomske aktivnosti u Republici Hrvatskoj. Metodološka unaprijeđenja se odnose na metodu izbora komponenti indeksa te na određivanje točaka zaokreta poslovnog ciklusa. Točke zaokreta poslovnog ciklusa se određuju korištenjem filtrirane serije vjerojatnosti ulaska u recesiju izračunate primjenom modela Markovljevih lanaca, dok se izbor komponenti indeksa provodi testovima značajnosti koeficijenta korelacije te ocjenom logit modela. Novi CROLEI indeks se sastoji od osam komponenti te predstavlja unaprijeđenje u odnosu na postojeći indeks, kako u smislu modernije metodologije, tako i u smislu pravovremenog naviještanja točaka zaokreta poslovnog ciklusa.

Ključne riječi: navješćujući indeks, Markovljevi lanci, logit model, Hrvatska

* I. Rašić Bakarić, dr. sc., znanstvena suradnica u Ekonomskom institutu, Zagreb (e-mail: irasic@eizg.hr).

** M. Tkalec, asistentica u Ekonomskom institutu, Zagreb (e-mail: mtkalec@eizg.hr).

*** M. Vizek, dr. sc., znanstvena suradnica u Ekonomskom institutu, Zagreb (e-mail: mvizek@eizg.hr).

Prvobitna verzija članka primljena je u uredništvo 8. 08., a definitivna 13. 12. 2011.

1. Uvod

Navješćujući indeksi su u središtu akademskih proučavanja i rasprava još od davne 1938. godine kada su Mitchell i Burns (Mitchell i Burns, 1938.) u sklopu National Bureau of Economic Research (NBER) definirali koncept navješćujućih i pratećih pokazatelja. Od tada se navješćujući pokazatelji smatraju praktičnim alatom za prognoziranje promjena u poslovnom ciklusu te ih zbog njihove praktičnosti i jednostavnosti za vlastite prognostičke potrebe često koriste kako nositelji ekonomskih politika, tako i poslovni sektor. Uporabna vrijednost navješćujućih indikatora se značajno povećavala kako su rasle spoznaje proizašle iz intenzivnijeg istraživanja ove teme u zadnja dva desetljeća. Stoga se danas navješćujući indikatori koriste ne samo za prognoziranje kretanja poslovnog ciklusa i raznih makroekonomskih agregata, nego i za ocjenu pokazatelja trenutnog stanja poslovnog ciklusa (Filardo, 1994.).

CROLEI (engl. *Croatian Leading Economic Indicator*) je prvi navješćujući indeks izrađen za potrebe prognoziranja ekonomskih fluktuacija u Hrvatskoj. Konstruiran je na temelju NBER-ove metodologije navješćujućih pokazatelja te je istovremeno prilagođen ekonomskim okolnostima i institucionalnom okruženju u RH. Indeks se počeo javno objavljivati 1995. godine u Mjesečnom statističkom prikazu Ministarstva financija Republike Hrvatske. Složeni ili kompozitni indeks mjera je koja ukazuje na promjenu smjera kretanja agregatne ekonomske aktivnosti ili neke druge referentne serije. Takav indeks mjeri «prosječno» ponašanje grupe vremenskih serija koje predstavljaju aktivnosti i sektore jednoga gospodarstva (Moore i Shiskin, 1967.; Zarnowitz i Boschan, 1975.; Zarnowitz, 1992.). Zaokreti u kretanju tih vremenskih serija prethode zaokretima u kretanju odabrane referentne serije. Bilo koji navješćujući indeks, pa tako i CROLEI, sastoji se od nekolicine vremenskih serija od kojih se zahtijeva da zadovoljavaju sljedećih šest kriterija (Marcellino, 2006.):

1) konzistentno prethođenje poslovnog ciklusa (podrazumijeva sistematsko naviještanje točaka zaokreta, to jest vrhova i dna poslovnih ciklusa);

2) usuglašenost s poslovnim ciklusom (podrazumijeva sposobnost naviještanja općih tendencija poslovnog ciklusa, a ne samo točaka zaokreta u ciklusu);

3) ekonomska značajnost (podrazumijeva da ekonomska teorija odabrane vremenske serije smatra ili uzrocima promjene ciklusa ili varijablama koje brzo reagiraju na negativne ili pozitivne šokove u varijablama koje predstavljaju temeljne determinante poslovnih ciklusa);

4) statistička pouzdanost (podrazumijeva da su vremenske serije točan iskaz kvantitete promatrane ekonomske pojave);

5) statistička ažurnost (podrazumijeva da su nova opažanja pojedinih serija brzo dostupna te da nisu podložna naknadnim revizijama) i

6) izgladenost (podrazumijeva da serija nije karakterizirana visoko frekventnim i iregularnim oscilacijama).

Za razliku od proučavanja ekonomskih ciklusa u zemljama u kojima je dostupna opsežna statistička osnovica, istraživanje ekonomskih ciklusa u tranzicijskome gospodarstvu znatno je otežano zbog mnogih reformi koje su uzrokovale strukturne prekinde u serijama, zbog čega je statistička osnovica relativno sužena. Zbog navedenog ograničenja, u Hrvatskoj u ranijim razdobljima nakon stjecanja neovisnosti nije bilo moguće u cijelosti implementirati najnovije metodološke inovacije u području izrade navješćujućeg pokazatelja. No, u posljednjih desetak godina hrvatsko gospodarstvo prolazilo je kroz relativno stabilan period tijekom kojega se jedan dio ekonomskih pojava i procesa sustavno statistički pratio, što je stvorilo preduvjete za primjenu složenijih modelskih rješenja za izradu CROLEI indeksa.

Ostatak članka sastoji se od pet zasebnih cjelina. U sljedećem poglavlju dan je prikaz metodološke literature o navješćujućim pokazateljima te je opisan alternativni navješćujući indeks za Hrvatsku. U trećemu poglavlju prikazana je metodologija korištena za izradu CROLEI indeksa, dok su u četvrtome poglavlju opisani podaci koji se koriste u izradi i izračunu novog CROLEI indeksa. U petome poglavlju prikazani su rezultati primjene metodologije i vrijednosti novog CROLEI indeksa. U šestome, ujedno i završnom poglavlju, sažeto su prikazani temeljni zaključci koji proizlaze iz empirijske analize prikazane u članku.

2. Pregled literature

Pristupi izračunu najvešćujućih indikatora se dijele na nemodelske i modelske, pri čemu modelski pristup podrazumijeva određivanje točaka zaokreta i testiranja prethođenja primjenom ekonometrijskog modeliranja, dok nemodelski pristup podrazumijeva određivanje točaka zaokreta korištenjem determinističkih algoritama. U novijoj literaturi modelski pristup identificiranja točaka zaokreta i konstrukcije prethodećeg indeksa obuhvaća modele dinamičnih faktora (Stock i Watson, 1989.), Markovljeve lance (Hamilton, 1989.), ili kombinaciju ova dva pristupa. Bitno je naglasiti da specifikacija oba modela, i faktorskog dinamičkog i modela Markovljevih lanaca, zahvaća dva komplementarna i fundamentalna obilježja poslovnog ciklusa. Prvo je rasipanje (difuzija) usporavanja i oporavka kroz veliki broj nizova, a drugo je različito ponašanje nekoliko pokazatelja u ekspanziji i u recesiji. Obje metode odlikuju se snažnim i fleksibilnim statističkim alatima, te nalaze uporište u ekonomskoj teoriji.

Uz CROLEI indeks (Ahec - Šonje, 1995.; Bačić i Vizek, 2006.; Bačić i Vizek, 2008.) koji će biti pobliže opisan u sljedećem poglavlju članka, u Hrvatskoj je 2005. godine razvijen još jedan navješćujući pokazatelj (Cerovac, 2005.). Oba pokazatelja temelje se na nemodelskom pristupu, što podrazumijeva da se prilikom konstrukcije indeksa ne koriste gore opisanim metodama modelskog pristupa. Cerovac koristi kombinaciju različitih metodoloških koraka, koji se mogu pripisati nemodelskom pristupu sličnom NBER-ovoj metodologiji. Serija industrijske proizvodnje koristi se kao referentna serija, a točke zaokreta se određuju primjenom Bry-Boschanova algoritma. Da bi izabrao komponente navješćujućeg indeksa, autor primjenjuje korelacijsku analizu, pri čemu se uočene točke zaokreta modelski ne povezuju s potencijalnim komponentama navješćujućeg indeksa. Dobiveni navješćujući indeks se sastoji od ukupno tri komponente: prodajna marža; odnos depozita i kredita u sektoru poduzeća te odnos proizvodnje i zaliha u industriji.

3. Metodologija

3.1. Stara metodologija izračuna CROLEI indeksa

Metodologija izračuna CROLEI prethodećeg indeksa korištena do revizije napravljene u 2010. godini podrazumijeva sljedeće četiri temeljne odrednice:

1) korištenje indeksa fizičkog obujma industrijske proizvodnje kao referentne serije čije kretanje prognozira CROLEI indeks;

2) određivanje točaka zaokreta korištenjem Bry-Boschanova algoritma (Bry i Boschan, 1971.);

3) testiranje potencijalnih kandidata za komponente CROLEI indeksa na konzistentnost u prethođenju i usuglašenost s poslovnim ciklusom primjenom Grangerovog testa uzročnosti;

4) određivanje izgladenosti vremenskih serija korištenjem mjere MCD;

5) izbor najboljeg među konkurentskim verzijama CROLEI indeksa primjenom Grangerovog testa uzročnosti;

6) izračun CROLEI indeksa zasnovan na determinističkom algoritmu opisanom u Bačić i Vizek (2006.).

Detalji vezani uz staru metodologiju izračuna neće se detaljno opisivati u ovom članku, već se mogu pronaći u Bačić i Vizek (2006., 2008.). Prednosti stare metodologije zasnovane na nemodelskom pristupu u odnosu na novije metode za izračun prethodećih indeksa temeljene na ekonometrijskom pristupu su

mnogobrojne. Te metode su jednostavnije, puno lakše ih je primijeniti, objasniti i interpretirati, što je često izrazito važno nositeljima ekonomskih politika i široj javnosti. Također, jednostavnost je često karakteristika koja može unaprijediti točnost projekcija. Kod ove metodologije također nema problema s neizvjesnošću kod postupka ocjene te nema pojave takozvanog „overfittinga“ (situacije u kojoj ekonometrijski modeli korišteni u modelskom pristupu izračuna prethodećih indikatora ne mogu izvršiti ocjenu parametara jer su suočeni s prevelikim brojem nezavisnih varijabli).

Međutim ovaj nemodelski pristup ima i brojne nedostatke. Temeljni nedostatak, nastao kao posljedica ograničenja koja nameće neadekvatna statistička osnova (prekratke vremenske serije) i premali varijabilitet referentne serije (odsustvo dubljih recesija) je primjena Grangerovog testa uzročnosti (Granger, 1969.) u svrhu testiranja prva dva kriterija za odabir komponenata indeksa. Naime, stara metodologija izračuna CROLEI indeksa je testirala konzistentnost u prethođenju točaka zaokreta i usklađenost s kretanjem poslovnog ciklusa jednim statističkim testom – Grangerovim testom uzročnosti. Problem takvog pristupa se sagleda u činjenici da je Grangerov test uzročnosti prikladniji za određivanje serija koje zadovoljavaju kriterij usuglašenosti s poslovnim ciklusom, ali on ne može adekvatno detektirati serije koje konzistentno i sistematski prethode točkama zaokreta poslovnog ciklusa. Zbog istog razloga je problematična i primjena Grangerovog testa uzročnosti na izbor najboljeg između nekoliko potencijalnih CROLEI indeksa. Nadalje, premda su same točke zaokreta bile određene Bry-Boschan algoritmom, one u kasnijoj fazi konstrukcije indeksa nisu korištene u svrhu stohastičke ili determinističke ocjene sposobnosti vremenskih serija da predvide te točke zaokreta.

Drugi temeljni nedostatak jest korištenje serije industrijske proizvodnje kao referentne serije za određivanje datuma točaka zaokreta u poslovnom ciklusu. Naime, premda korištenje te serije ima neke prednosti poput mjesečne frekvencije podataka i kratkog roka objave podataka (oko dvadesetak dana nakon protoka promatranog mjeseca), ta serija ne sadrži informacije o točnom datumu kada je ekonomska aktivnost dosegla svoj vrhunac ili dno.

3.2. Nova metodologija izračuna CROLEI indeksa

Kako bi se uklonili nedostaci opisani u prethodnom poglavlju i modernizirao izbor komponenata CROLEI indeksa i njegov izračun, izrađena je nova metodologija izračuna CROLEI indeksa predstavljena u sljedećih sedam koraka:

1) korištenje metode Markovljevih lanaca za izračun referentne serije (serije vjerojatnosti ulaska u recesiju);

2) određivanje točaka zaokreta korištenjem serije vjerojatnosti ulaska u recesiju;

3) testiranje potencijalnih kandidata za komponente CROLEI indeksa na konzistentnost u prethodjenju korištenjem korelacijskih koeficijenata i logit modela;

4) testiranje potencijalnih kandidata za komponente CROLEI indeksa na usuglašenost s poslovnim ciklusom izračunom koeficijenta korelacije između prethodeće serije i serije BDP-a ocjenom statističke značajnosti izračunatog koeficijenta;

5) određivanje izgladenosti vremenskih serija korištenjem mjere MCD;

6) izračun CROLEI indeksa zasnovanog na determinističkom algoritmu opisanom u Bačić i Vizek (2006.).

Kao što je vidljivo, u ovoj reviziji su metodološke odrednice izmijenjene kako bi se uklonili nedostaci stare metodologije i kako bi se s nemodelskog prešlo na modelski pristup izračunu CROLEI indeksa.

3.2.1. Izračun vjerojatnosti ulaska u recesiju

Izračun serije vjerojatnosti ulaska u recesiju se temelji na modelu Markovljevih lanaca. Osnovni oblik modela Markovljevih lanaca dan je izrazom:

$$\Delta x_t = c_{s_t} + A_{s_t} \Delta x_{t-1} + u_t \quad (1)$$

$$u_t \sim N(0, \sigma^2) \quad (2)$$

pri čemu je x_t varijabla prateći pokazatelj (ili jedinstven kompozitni indeks), dok binarna varijabla s_t mjeri stanje poslovnog ciklusa, tako da u recesiji poprima vrijednost jedan ($s_t = 1$), dok u ekspanziji poprima vrijednost nula ($s_t = 0$). Obje se komponente, i deterministička i dinamička mijenjaju u različitim fazama poslovnog ciklusa. Binarna varijabla stanja, s_t nije izravno mjerljiva, ali odražava informacije sadržane u koincidentnom pokazatelju.

Za izračun referentne serije primijenjen je Hamiltonov model Markovljevih lanaca (Hamilton, 1989.). Hamilton u svom modelu polazi od pretpostavke da prve diferencije opazive serije slijede nelinearni stacionarni proces. S obzirom da se zaokreti poslovnog ciklusa ne mogu izravno opaziti, Hamilton je konstruirao algoritam za izračun vjerojatnosti događaja (zaokreta) na temelju opaženog ponašanja serije. Algoritam ima formu nelinearnog iterativnog filtra, koji omogućava pro-

cjenu parametara populacije putem metode najveće vjerodostojnosti (MLE algoritam) te pruža osnovu za predviđanje budućih vrijednosti serije.

Hamilton je zapravo proširio osnovni model Markovljevih lanaca (1) - (2) uvođenjem jednadžbe koja definira uvjete na s_t varijablu s_t . S obzirom da je s_t binarna varijabla, jednadžba ne može biti autoregresijska¹.

$$\Pr(s_t = j | s_{t-1} = i) = p_{ij} \quad (3)$$

Osnovna svrha modela je procijeniti neopažljivo trenutno stanje gospodarstva, pretpostavljajući srednje kvadratnu pogrešku funkcije gubitka, da najbolji procjenitelj koincidira s uvjetnim očekivanjima s_t uz dane tekuće i prošle informacije o x_t , što je ekvivalentno uvjetnoj vjerojatnosti:

$$\zeta_{t|t} = \begin{cases} \Pr(s_t = 0 | x_t, x_{t-1}, \dots, x_1) \\ \Pr(s_t = 1 | x_t, x_{t-1}, \dots, x_1) \end{cases} \quad (4)$$

Za detaljan izvod ovih izračuna vidjeti Hamilton (1994.) ili Krolzig (1997.). Valja naglasiti da se osim MLE algoritma, u literaturi koriste još dva algoritma za procjenu funkcije najveće vjerodostojnosti (4): EM (expectations maximization) i MCMC (Bayesian Markov Chain Monte Carlo) algoritam. U ovom radu bit će primijenjen EM algoritam. Hamilton (1994.) i Krolzig (1997.) navode i izraz za izračun izgladenog procjenitelja vjerojatnosti stanja u trenutku t $\zeta_{t|T}$. Iz prvog i posljednjeg reda izraza (4) vidi se da je i funkcija vjerojatnosti stanja i gustoće varijabli uvjetovana isključivo prošlim informacijama.

3.2.2. Testiranje komponenti CROLEI indeksa na usklađenost s poslovnim ciklusom

Ispunjavanje kriterija usklađenosti s poslovnim ciklusom se ispituje izračunom korelacijskih koeficijenata između potencijalnih komponenti CROLEI indeksa i BDP-a, te ocjenom statističke značajnosti tih koeficijenata. S obzirom da se radi o numeričkim varijablama koje slijede normalnu distribuciju, i o uzorku (vremenske serije) većem od 30 jedinica ($n > 30$), za utvrđivanje jakosti i smjera linearne povezanosti dviju varijabli korišten je Pearsonov koeficijent korelacije (koeficijent jednostavne linearne korelacije). Koeficijent linearne korelacije definiran je izrazom:

¹ S obzirom na svojstvo binarnosti varijable stanja s_t .

$$r = \frac{Cov(X, Y)}{\sigma_x \sigma_y} - 1 \leq \rho \leq 1 \quad (5)$$

gdje je r - Pearsonov koeficijent korelacije, $\sigma_x \sigma_y$ - standardne devijacije varijabli X i Y , a $Cov(X, Y)$ - kovarijanca² između varijabli X i Y . Linearna povezanost dviju varijabli može biti pozitivna i negativna (Šošić, 2006.).

Nakon izračuna korelacijskih koeficijenata provedeni su dvosmjerni testovi značajnosti Pearsonovog koeficijenta korelacije. Testiranje statističke značajnosti Pearsonovog koeficijenta korelacije vrši se pomoću Studentove (t-distribucije) odnosno t-testa, za $n-2$ stupnja slobode odnosno na temelju usporedbe empirijske (p-vrijednost) i teorijske razine signifikantnosti (α), pri čemu je izraz za t-omjer:

$$t = r \sqrt{\frac{n-2}{1-r^2}} \quad (6)$$

3.2.3. Testiranje komponenti CROLEI indeksa na konzistentnost u prethođenju

Ispunjavanje kriterija konzistentnosti u prethođenju testira se logit modelom, s tim da je zavisna varijabla modela binarna varijabla izračunata korištenjem serije vjerojatnosti ulaska u recesiju dobivene ocjenom modela Markovljevih lanaca.³ Logit modele izvodimo pomoću latentne varijable y^* koju ne opažamo, ali je definiramo pomoću regresijskog modela s klasičnim pretpostavkama:

$$\begin{aligned} y^* &= \beta_0 + x\beta + e \\ y &= 1 [y^* > 0] \end{aligned} \quad (7)$$

² Kovarijanca predstavlja mjeru sukladnosti variranja dviju varijabli, ali za razliku od korelacije nije standardizirana na interval od -1 do +1, već njena veličina ovisi o stupnju povezanosti dviju varijabli i veličini njihovih standardnih devijacija. U slučaju kada su obje varijable izražene u z-vrijednostima (standardizirane) kovarijanca je identična Pearsonovom koeficijentu korelacije.

³ Transformacija vjerojatnosti ulaska u recesiju u binarnu varijablu i konzekventna primjena logit modela je neophodna da bi se mogla testirati sposobnost komponenti navješćujućeg indeksa da predviđaju točke zaokreta. Teoretski i sama serija vjerojatnosti ulaska u recesiju se mogla staviti kao zavisna varijabla što bi dovelo do primjene tobit umjesto logit modela. No u tom slučaju bismo umjesto konzistentnosti u prethođenju, zapravo testirali usklađenost komponenti s kretanjem poslovnog ciklusa jer nam jedino transformacija vjerojatnosti ulaska u recesiju u binarnu varijablu omogućuje egzaktno datiranje točaka zaokreta poslovnog ciklusa i modelsko povezivanje tih točaka s komponentama indeksa.

Iz prikazanoga slijedi da latentna varijabla pomaže u konstrukciji indikator varijable y_i koja poprima vrijednost jedan ukoliko je latentna varijabla veća od nule, te vrijednost nula ukoliko je latentna varijabla manja ili jednaka nuli. Ocjena binarnih modela nije moguća metodom najmanjih kvadrata iz razloga što nema slučajne greške, a time niti sume kvadrata grešaka koju bismo minimizirali. Osim toga, svako opažanje zavisne varijable uvjetovano je vrijednostima nezavisne varijable pa je i gustoća zavisne varijable zapravo uvjetna gustoća. Na razini cijeloga uzorka tada imamo uvjetnu zajedničku gustoću koja je umnožak uvjetnih individualnih gustoća svih y_i . Ta zajednička uvjetna gustoća naziva se još i funkcija vjerojatnosti jer daje vjerojatnost opažanja promatranog uzorka. Logaritamsku transformaciju funkcije vjerojatnosti možemo zapisati na sljedeći način:

$$\begin{aligned}\ell_i(\beta) &= y_i \log [G(x_i\beta)] + (1 - y_i) [1 - G(x_i\beta)] \\ L(\beta) &= \sum_{i=1}^n \ell_i(\beta)\end{aligned}\quad (8)$$

gdje je $L(\beta)$ log-funkcija vjerojatnosti za uzorak veličine n . Maksimizacija obiju funkcija vjerojatnosti daje parametar distribucije koji opaženi uzorak čini najvjerojatnijim. Taj parametar se naziva MLE (prema engl. Maximum Likelihood Estimator) i označavamo ga s β . MLE je konzistentan, asimptotski normalan i asimptotski učinkovit procjenitelj (Wooldridge, 1999.). Svaki β_j ima pripadajuću standardnu grešku pomoću koje je moguće konstruirati t testove kao i intervale pouzdanosti. Vektor procijenjenih MLE parametara dobiva se numeričkim metodama jer analitičko rješenje funkcije vjerojatnosti ne postoji. Za određivanje globalnog maksimuma postoji niz optimizacijskih algoritama, a kako je logaritmirana funkcija vjerojatnosti konkavna funkcija, svaki algoritam će uvijek pronaći globalni maksimum. Stoga je nužno provjeriti robusnost rezultata procjene s obzirom na različite algoritme.

Mjera izgladenosti serija se u svim dosadašnjim revizijama, pa tako i u ovoj, nije mijenjala. Koristila se mjera MCD, koja predstavlja broj mjeseci u kojima iregularna komponenta serije nadvladava cikličnu komponentu. Također se nije mijenjao niti završni korak – izračun CROLEI indeksa temeljen na determinističkom komponiranju vremenskih serija, premda je prvotna namjera bila da se i taj korak modernizira, odnosno da ga se zamijeni modelskim pristupom. Naime, idealno bi bilo koristiti logit model kojim bi se svaki mjesec po pristizanju podataka za svih osam komponenti novog indeksa projicirala vjerojatnost ulaska u recesiju za buduće razdoblje određeno prosječnim vremenom prethođenja. Taj korak bi potpuno zamijenio determinističko računanje indeksa, pa bi umjesto CROLEI indeksa rezultat CROLEI prognostičkog sustava bila projekcija vjerojatnosti ulaska u recesiju. Prednost ovog pristupa je i činjenica da za takvu projekciju možemo izračunati i pripadajuću slučajnu grešku jer je ta projekcija izrađena modelskim

putem. Takvo što nije bilo moguće kod projekcija zasnovanih na kretanju vrijednosti starog CROLEI indeksa. No nažalost, takav pristup nije bilo moguće provesti zbog pojave takozvanog „overfittinga“ nastalog zbog premalog varijabiliteta korištene referentne serije i kratkoće ocijenjenih vremenskih serija, koji su onemogućili da se ocijeni logit model sa osam varijabli (odnosno komponenti).

4. Podaci

Statistička baza potrebna za izbor optimalnih komponenti i izračun CROLEI indeksa raspolaže s 278 vremenskih serija mjesečne frekvencije koje su raspoložive od siječnja 1998. do listopada 2010. godine. Vremenske serije pokrivaju sva najznačajnija područja hrvatskog gospodarstva i mogu se svrstati u sljedeća područja:

- 1) Cijene industrijskih proizvoda (8 pokazatelja)
- 2) Potrošačke cijene (20 pokazatelja)
- 3) Industrijska proizvodnja (40 pokazatelja)
- 4) Graditeljstvo (3 pokazatelja)
- 5) Trgovina (1 pokazatelj)
- 6) Turizam (6 pokazatelja)
- 7) Nezaposlenost (7 pokazatelja)
- 8) Zaposlenost (24 pokazatelja)
- 9) Bruto plaće (23 pokazatelja)
- 10) Neto plaće (24 pokazatelja)
- 11) Tržište kapitala (2 pokazatelja)
- 12) Monetarna statistika (66 pokazatelja)
- 13) Fiskalna statistika (17 pokazatelja)
- 14) Međunarodna statistika (15 pokazatelja)
- 15) Međunarodna razmjena (22 pokazatelja)

U okviru pripreme statističke podloge obavlja se deflacioniranje nominalnih serija te desezoniranje svih serija. To je nužan metodološki korak s obzirom na to da je gotovo svaka ekonomska serija pod utjecajem sezonskih učinaka i da gotovo svaka serija iskazuje iregularnost u svojem kretanju. Stoga je dekompozicijom vremenskih serija potrebno odvojiti sezonsku komponentu od trend-ciklusa i iregularne komponente na način da se zadrže osnovna svojstva originalne ekonomske serije. Desezoniranje se provodi uz pomoć metode X12ARIMA. Na osnovi rezultata desezoniranja, računa se i mjera MCD, potrebna za ocjenu izgladenosti serije.

5. Rezultati

Prvi korak u formiranju CROLEI navješćujućeg indeksa predstavlja izbor referentne serije. U svrhu određivanja referentne serije, primijenili smo model Markovljevih lanaca koji endogeno procjenjuje datum promjene režima (odnosno faze poslovnog ciklusa) u parametrima modela na osnovi ocjene izglađene vjerojatnosti ulaska u recesiju. Model primjenjujemo na seriji fizičkog obujma industrijske proizvodnje koja je dostupna na mjesečnoj razini.⁴

Rezultati ocjene parametara modela prikazani su u tablici 1, dok je serija vjerojatnosti ulaska u recesiju prikazana zajedno sa serijom indeksa volumena industrijske proizvodnje na slici 1.

Tablica 1.

PROCIJENJENE VRIJEDNOST PARAMETARA MARKOVLJEVOG MODELA ZA SERIJU INDUSTRIJSKE PROIZVODNJE

Parametar	Procijenjena vrijednost	Standardna greška	p - vrijednost
μ_1	-0,738	0,401	0,065
μ_2	0,298	0,126	0,018
p	0,887	0,153	0,000
q	0,021	0,029	0,469
σ	7,015	0,620	0,000

Izvor: izračun autorica.


⁴ Valja napomenuti da takav odabir ima svoje prednosti i nedostatke. Naime, premda je cilj revizije prijeći na potpuno modelski pristup izračunu CROLEI indeksa, neizbježno je izračun indeksa početi s jednom egzogeno zadanom pretpostavkom. U ovom slučaju ta pretpostavka glasi da industrijska proizvodnja dobro odražava kretanje ukupne ekonomske aktivnosti u zemlji, a ona je potvrđena kroz mnogobrojna istraživanja koja tu istu seriju koriste za aproksimiranje cikličkih kretanja (npr. vidi Cerovac, 2005.; Bačić i Vizek, 2006.; Vizek, 2006.) koja sugeriraju da je korištenje industrijske proizvodnje u svrhu ocjene vjerojatnosti ulaska u recesiju primjenom Markovljevih lanaca opravdano. S druge strane, korištenje bilo koje druge mjesečne serije ili indeksa sastavljenog od nekoliko serija koje dobro aproksimiraju kretanja ekonomskog ciklusa značilo bi uvođenje pretpostavke da ta serija ili serije također dobro aproksimiraju kretanje poslovnog ciklusa, premda tu pretpostavku (kao uostalom ni prvu pretpostavku) nije moguće direktno dokazati jer je izvorni poslovni ciklus neopaziv. No za razliku od prve pretpostavke, za koju indirektnu potkrjepu možemo naći u domaćoj literaturi, za drugu pretpostavku takvih dokaza nema.

Vrijednosti ocijenjenih parametara sugeriraju da doista postoje dvije zasebne faze rasta koje karakteriziraju seriju industrijske proizvodnje. Ocjene vrijednosti parametara μ_1 i μ_2 koje ujedno predstavljaju i takozvane „state-dependent“ sredine (sredine ovisne o pretpostavljenom stanju, s tim da se pretpostavljaju dva stanja) se statistički razlikuju jedna od druge, a ujedno se razlikuju i njihove veličine i predznaci što je vrlo bitno za ekonomsku interpretaciju. Ako je suditi prema vrijednosti asimptotske standardne greške i pripadajuće p-vrijednosti za stanje 1, prosječna mjesečna stopa promjene u tom stanju (μ_1) je negativna (-0,738) i statistički značajna, dok je prosječna stopa promjene u stanju 2 (μ_2) pozitivna (0,298) i statistički značajna. Time je ispunjen preduvjet kojeg Markovljev model mora zadovoljiti da bi uspješno opisao kontrakcije i ekspanzije gospodarske aktivnosti (Filardo, 1994.). Budući da se čitav uzorak može podijeliti u dva odvojena stanja koja iskazuju ili pad ili rast outputa, ta dva stanja možemo stoga klasificirati kao kontrakciju ili ekspanziju poslovnog ciklusa.

Seriya vjerojatnosti ulaska u recesiju izračunata na osnovi ocijenjenih parametara Markovljevog modela prikazana je na slici 1.

Slika 1.

IZGLAĐENA VJEROJATNOST ULASKA U RECESIJU I TOČKE ZAOKRETA POSLOVNOG CIKLUSA



Izvor: izračun autorica.

U literaturi se uglavnom pretpostavlja da vrijednosti vjerojatnosti veće od 0,5 označavaju recesiju, a vrijednosti manje od 0,5 predstavljaju ekspanziju (Hamilton, 1989.; Marcellino, 2006.) pa stoga na osnovi ocijenjene vjerojatnosti ulaska u recesiju možemo izračunati vrhove i dna poslovnog ciklusa. Vrh poslovnog ciklusa definiramo kao ono razdoblje u kojem je izgladena vrijednost ulaska u recesiju bila manja od 0,5, nakon čega se u sljedećim razdobljima povećala na vrijednost jednaku ili veću od 0,5. Dno poslovnog ciklusa definiramo kao ono razdoblje u kojem je vrijednost izgladene vjerojatnosti bila veća ili jednaka 0,5, nakon čega se u sljedećim razdobljima smanjila na vrijednost manju od 0,5. Na takav način možemo definirati dva vrha poslovnog ciklusa: jedan u kolovozu 1998., a drugi u svibnju 2008. Prvo dno poslovnog ciklusa se može identificirati u prosincu 1998., dok se drugo dno ciklusa dogodilo u rujnu 2009.⁵

Izračuni koeficijenata korelacije između potencijalnih komponenti CROLEI indeksa i serije bruto domaćeg proizvoda te ocjena njihove signifikantnosti prikazani su u tablici 2. Testirana je značajnost korelacijskih koeficijenata između godišnjih stopa rasta pokazatelja i stopa rasta bruto domaćeg proizvoda te između razina pokazatelja i razina serije bruto domaćeg proizvoda za razdoblje od prvoga tromjesečja 1999. do trećega tromjesečja 2010. za svih 278 serija iz statističke baze. Testovi značajnosti koeficijenata korelacije provedeni su za svaki pojedini vremenski pomak odabrane vremenske serije (pokazatelja) u odnosu na tekuću vrijednost referentne serije, pri čemu vrijeme prethođenja serije iznosi najmanje tri mjeseca (jedno tromjesečje), a najviše 12 mjeseci (četiri tromjesečja). U tablici su prikazani rezultati za serije koje su ostvarile statistički značajne i velike koeficijente korelacije izračunate za serije u godišnjim stopama. Svi ostali rezultati mogu se dobiti po upitu autoricama. Valja napomenuti da su samo serije koje su zabilježile signifikantne i velike vrijednosti koeficijenata korelacije testirane na konzistentnost u prethođenju točaka zaokreta poslovnog ciklusa pomoću logit modela.

Nakon što smo temeljem korelacijske analize utvrdili koji pokazatelji dobro navješćuju ukupne promjene poslovnoga ciklusa, preostaje nam da primjenom logit modela odredimo koje od tih serija dobro navješćuju točke zaokreta (vrhove i dna poslovnog ciklusa). Zavisna varijabla logit modela je transformirana serija mjesečnih vjerojatnosti ulaska u recesiju. Za transformaciju je primijenjeno sljedeće pravilo: svim vrijednostima izgladene vjerojatnosti ulaska manjima od 0,5 je dodijeljena vrijednost 0, dok je svim preostalim vrijednostima (vrijednostima većima ili jednakima 0,5) dodijeljena vrijednost 1. Mjesečne stope rasta varijabli popisanih u tablici 2 koristit će se kao nezavisne varijable. Prvo ocjenjujemo

⁵ Zbog činjenice da je recesija u Hrvatskoj prema podacima o BDP-u trajala do drugog tromjesečja 2011., drugo dno ciklusa datirano u rujnu 2009. godine treba shvatiti kao prestanak pada ekonomske aktivnosti i početak produljene stagnacije, a ne kao početak ekonomskog oporavka.

širi logit model koristeći Newton-Raphson algoritam koji se sastoji od zavisne varijable, konstante te potencijalnog pokazatelja koji u model ulazi s četvrtim, petim, šestim, pa sve do 14. vremenskog pomaka. Nakon toga isti model ocjenjujemo s više različitih optimizacijskih algoritama te Probit modelom kako bismo se uvjerali u robusnost rezultata dobivenih Newton-Raphson algoritmom. Na temelju izračunatih z-Statistika i njihovih p-vrijednosti odabiremo najznačajniji pomak pokazatelja te ocjenjujemo i uži model koji se sastoji od zavisne varijable, konstante te potencijalnog pratećeg pokazatelja u najznačajnijem vremenskome pomaku. Tablica 3 prikazuje rezultate logit ocjene užih modela za prethodeće pokazatelje, dok se rezultati ocjene širih modela koji su u osnovi jako slični rezultatima užih modela mogu dobiti upitom autoricama.

Tablica 2.

**KOEFICIJENTI KORELACIJE POTENCIJALNIH NAVJEŠĆUJUĆIH
POKAZATELJA I BDP-A U GODIŠNJIM STOPAMA I NJIHOVA
STATISTIČKA SIGNIFIKANTNOST**

Naziv serije	Vremenski pomak			
	t-1	t-2	t-3	t-4
Indeksi cijena intermedijarnih proizvoda	0,17	-0,09	-0,36	-0,56
Indeks cijena građevinskog materijala	0,33	0,41	0,48	0,53
Temeljni indeksi potrošačkih cijena – Dobra	-0,24	-0,45	-0,59	-0,69
Proizvodnja ostalih nemetalnih mineralnih proizvoda	0,78	0,70	0,60	0,46
Izvoz sirove energije, osim goriva	0,45	0,50	0,47	0,35
Izvoz kemijskih proizvoda	0,45	0,31	0,18	0,04
Uvoz strojeva i transportnih uređaja	0,80	0,70	0,46	0,24
Zaposlenost - Financijske uslužne djelatnosti, osim osiguranja i mirovinskih fondova	0,61	0,48	0,32	0,13
Neto plaća - Proizvodnja proizvoda od gume i plastike	0,63	0,54	0,51	0,43
Bruto plaća - Proizvodnja koksa i rafiniranih naftnih proizvoda	0,24	0,32	0,30	0,20
Prihodi od trošarina (ukupno)	0,15	0,22	0,26	0,38
Prihodi od carina	0,10	0,11	0,25	0,29
Prihodi od poreza na dobit	0,40	0,34	0,26	0,20
CROBEX	0,61	0,64	0,62	0,49
Ukupni promet na ZSE	0,58	0,55	0,52	0,49
Novčana masa M1	0,68	0,64	0,57	0,44
Novčana masa M1a	0,68	0,64	0,57	0,43
Depozitni novac	0,69	0,63	0,55	0,40

Naziv serije	Vremenski pomak			
	-0,59	-0,68	-0,82	-0,85
Kamatne stope na lombardne kredite	-0,59	-0,68	-0,82	-0,85
Spread: Dugoročni krediti s valutnom klauzulom - oročeni devizni depoziti u eurima - trgovačkim društvima	-0,74	-0,76	-0,77	-0,72
Spread: Dugoročni krediti s valutnom klauzulom - oročeni devizni depoziti u eurima - stanovništvu	-0,76	-0,75	-0,74	-0,66
Spread: Dugoročni devizni depoziti RH (poduzeća) - EU12 mjesečna kamatna stopa na tržištu novca	-0,69	-0,67	-0,62	-0,50
Spread: Dugoročni kredit s valutnom klauzulom RH (ukupni prosjek) - EU12 mjesečna kamatna stopa na tržištu novca	-0,78	-0,76	-0,72	-0,56
Indeks volumena industrijske proizvodnje – EU27	0,65	0,67	0,58	0,43
Indeks volumena industrijske proizvodnje – EU16	0,66	0,68	0,59	0,44
Indeks volumena industrijske proizvodnje – EU15	0,64	0,67	0,58	0,43
Indeks volumena industrijske proizvodnje – Njemačka	0,61	0,62	0,52	0,35
Indeks volumena proizvodnje prerađivačke industrije – EU27	0,66	0,67	0,57	0,42
Indeks volumena proizvodnje prerađivačke industrije – EU16	0,66	0,68	0,59	0,44
Indeks volumena proizvodnje prerađivačke industrije – EU15	0,64	0,66	0,58	0,42
Indeks volumena proizvodnje prerađivačke industrije – Njemačka	0,61	0,61	0,51	0,34
Indeks novih narudžbi u industriji – EU27	0,58	0,63	0,57	0,43
Indeks novih narudžbi u industriji – EU16	0,58	0,63	0,57	0,44
Indeks novih narudžbi u industriji – Njemačka	0,56	0,62	0,59	0,45
Indeks novih narudžbi u industriji – Italija	0,59	0,63	0,54	0,39

Napomena. Podebljani su koeficijenti korelacije koji su signifikantni uz teorijsku razinu signifikantnosti od 5%.

Izračun autorica.

Tablica 3.

REZULTATI OCJENE LOGIT MODELA

	REZULTATI OCJENE LOGIT MODELA						MCD-mjera „izglađenosti“ serije
	Pomak	Predznak	z-statistika (p-vrijednost)	McFadden R ²	Schwarzov informativni kriterij	LR statistika (p-vrijednost)	
Indeksi cijena intermedijarnih proizvoda	-9	+	3.22*** (0.00)	0.83	0.20	77.57*** (0.00)	1
Indeks cijena građevinskog materijala	-8	+	3.06*** (0.00)	0.83	0.19	77.98*** (0.00)	1
Temeljni indeksi potrošačkih cijena - Dobra	-4	+	4.07*** (0.00)	0.75	0.25	70.86*** (0.00)	1
Proizvodnja ostalih nemetalnih mineralnih proizvoda	-12	-	-3.71*** (0.00)	0.09	0.72	8.76*** (0.00)	6
Izvoz sirove energije, osim goriva	-4	-	-3.59*** (0.00)	0.17	0.64	16.58*** (0.00)	5
Izvoz kemijskih proizvoda	-12	+	2.81*** (0.00)	0.06	0.74	5.83** (0.02)	6
Uvoz strojeva i transportnih uređaja	-4	-	-1.99** (0.047)	0.06	0.71	5.74** (0.02)	6
Zaposlenost - Financijske usluzne djelatnosti, osim osiguranja i mirovinskih fondova	-7	+	4.41*** (0.00)	0.33	0.54	31.09*** (0.00)	3
Neto plaća - Proizvodnja proizvoda od gume i plastike	-9	-	-3.59*** (0.00)	0.19	0.64	17.47*** (0.00)	5
Bruto plaća - Proizvodnja koksa i rafiniranih naftnih proizvoda	-10	-	-3.69*** (0.00)	0.16	0.66	15.19*** (0.00)	5
Prihodi od trošarina (ukupno)	-9	-	-2.83*** (0.00)	0.07	0.72	6.64** (0.009)	12
Prihodi od carina	-10	-	-3.37*** (0.00)	0.03	0.75	3.07 (0.08)	6

	REZULTATI OCJENE LOGIT MODELA						MCD-mjera „izglađenosti“ serije
	Pomak	Predznak	z-statistika (p-vrijednost)	McFadden R ²	Schwarzov informacijski kriterij	LR statistika (p-vrijednost)	
Prihodi od poreza na dobit	-12		3,60 (0,00)***	0,12	0,69	11,56 (0,00)	12
CROBEX	-8	-	-2,10** (0,04)	0,07	0,72	6,53** (0,01)	2
Ukupni promet na ZSE	-6	-	-3,35*** (0,00)	0,32	0,54	30,43*** (0,00)	5
Novčana masa M1	-7	-	-2,85*** (0,00)	0,13	0,67	12,47*** (0,00)	5
Novčana masa M1a	-11	-	-2,49*** (0,00)	0,09	0,72	7,97*** (0,00)	5
Depozitni novac	-4	-	-4,39*** (0,00)	0,22	0,60	20,79*** (0,00)	2
Kamatne stope na lombardne kredite	-4	-	-4,44*** (0,00)	0,22	0,60	20,92*** (0,00)	2
Spread: Dugoročni krediti s valutnom klauzulom - oročeni devizni depoziti u eurima - trgovačkim društvima	-4	-	-4,45*** (0,00)	0,23	0,60	21,47*** (0,00)	2
Spread: Dugoročni krediti s valutnom klauzulom - oročeni devizni depoziti u eurima - stanovništvu	-6	+	5,60*** (0,00)	0,32	0,54	30,43*** (0,00)0	4
Spread: Dugoročni devizni depoziti RH (poduzeća) - EU12 mjesečna kamatna stopa na tržištu novca	-4	+	6,05*** (0,00)	0,31	0,54	29,61*** (0,00)	3
Spread: Dugoročni kredit s valutnom klauzulom RH (ukupni prosjek) - EU12 mjesečna kamatna stopa na tržištu novca	-4	+	3,36*** (0,00)	0,09	0,69	8,55*** (0,00)	3
Indeks volumena industrijske proizvodnje – EU27	-4	+	3,88*** (0,00)	0,12	0,67	11,72*** (0,00)	2
Indeks volumena industrijske proizvodnje – EU16	-19	+	4,65*** (0,00)	0,16	0,69	14,97*** (0,00)	2

	REZULTATI OCJENE LOGIT MODELA						MCD-mjera „izgladenosti“ serije
	Pomak	Predznak	Z-statistika (p-vrijednost)	McFadden R ²	Schwarzov informacijski kriterij	LR statistika (p-vrijednost)	
Indeks volumena industrijske proizvodnje – EU15	-20	+	4,52*** (0,00)	1,15	0,71	13,54*** (0,00)	2
Indeks volumena industrijske proizvodnje – Njemačka	-19	+	4,53*** (0,00)	0,16	0,70	14,22*** (0,00)	2
Indeks volumena proizvodnje prerađivačke industrije – EU27	-17	+	4,30*** (0,00)	0,17	0,60	26,27*** (0,00)	2
Indeks volumena proizvodnje prerađivačke industrije – EU16	-19	+	3,61*** (0,00)	0,35	0,55	32,56*** (0,00)	2
Indeks volumena proizvodnje prerađivačke industrije – EU15	-18	+	4,29*** (0,00)	0,17	0,68	5,45*** (0,00)	2
Indeks volumena proizvodnje prerađivačke industrije – Njemačka	-17	+	4,12*** (0,00)	0,12	0,71	11,21*** (0,00)	2
Indeks novih narudžbi u industriji – EU27	-18	+	4,37*** (0,00)	0,17	0,68	15,73*** (0,00)	2
Indeks novih narudžbi u industriji – EU16	-19	+	4,31*** (0,00)	0,32	0,57	29,81*** (0,00)	2
Indeks novih narudžbi u industriji – Njemačka	-13	+	2,11*** (0,00)	0,05	0,75	4,95** (0,03)	3
Indeks novih narudžbi u industriji – Italija	-16	+	3,87*** (0,00)	0,13	0,71	11,93*** (0,00)	5
Indeksi cijena intermedijarnih proizvoda	-16	+	3,64*** (0,00)	0,11	0,72	9,83*** (0,00)	3
Indeks cijena građevinskog materijala	-16	+	2,88*** (0,00)	0,05	0,76	4,88*** (0,00)	5

Napomena: *** - značajno na razini signifikantnosti od 1%, ** - značajno na razini signifikantnosti od 5%, * - značajno na razini signifikantnosti od 10%.

Izračun autorica.


Pregledom rezultata prikazanih u tablici 2 i 3 možemo uočiti da pobrojanih 35 vremenskih serija uglavnom zadovoljava i kriterij usklađenosti s poslovnim ciklusom i kriterij prethođenja točkama zaokreta. No budući da se CROLEI indeks ne može sastojati od 35 serija, konačni odabir komponenti CROLEI indeksa, osim na rezultatima korelacijske i logit analize, se temelji i na niskoj ili zanemarivoj iregularnoj komponenti u kretanju serije mjerene MCD pokazateljem (poželjna je što manja vrijednost tog pokazatelja), dovoljno dugačkom vremenu prethođenja te većem stupnju agregacije vremenske serije. Uzimajući u obzir rezultate korelacijske analize, ocjene logit modela te gore navedene kriterije, sljedećih osam vremenskih serija je izabrano za nove komponente CROLEI indeksa:

- Prosječna bruto plaća u sektoru proizvodnje koksa i rafiniranih naftnih proizvoda;
- Indeks volumena proizvodnje ostalih nemetalnih mineralnih proizvoda;
- Uvoz strojeva i transportnih uređaja;
- Indeks volumena proizvodnje prerađivačke industrije u EU15;
- Indeks novih narudžbi u prerađivačkoj industriji u EU27;
- CROBEX indeks;
- Razlika između kamate na dugoročne kredite s valutnom klauzulom trgovačkim društvima i oročene devizne depozite u eurima trgovačkim društvima;
- Prihodi državnog proračuna od poreza na međunarodnu trgovinu i transakcije (prihodi od carina).

Algoritam izračuna CROLEI indeksa od 8 navedenih serija sastoji se od nekoliko računskih koraka koji nisu opisani u ovome članku. Za detalje vidi Bačić i Vizek (2008.). Kretanje novog CROLEI indeksa prikazano je na slici 2. usporedo s kretanjem CROLEI indeksa izračunatog primjenom stare metodologije i vrhovima poslovnog ciklusa izračunatih primjenom modela Markovljevih lanaca. Sa slike je vidljivo da je vrijednost CROLEI indeksa dosegla svoj vrhunac tijekom 1998. i 2008. godine otprilike dva tromjesečja prije no što je poslovni ciklus zabilježio svoj vrh, što znači da indeks uspješno naviješta zaokrete poslovnog ciklusa, odnosno u ovom slučaju recesiju. Nadalje, iako se CROLEI indeks djelomično oporavio nakon intenzivnog pada vrijednosti tijekom 2008. godine, primjetno je da je njegova vrijednost tijekom 2009. i 2010. kolebljiva te da ne upućuje trajan gospodarski oporavak. Za razliku od novog CROLEI indeksa, CROLEI indeks dobiven primjenom stare metodologije ne najavljuje niti jednu od dvije recesije te su mu se vrijednosti sredinom 2009. počele oporavljati sugerirajući skori oporavak ekonomske aktivnosti.

Slika 2.

KRETANJE CROLEI INDEKSA U RAZDOBLJU OD 1998. DO 2010. GODINE



Izvor: izračun autorica.

6. Zaključak

U gospodarstvu poput hrvatskoga, primjena metode navješćujućih indikatora još uvijek predstavlja veliki izazov za istraživača. Premda je od početka tranzicije prošlo dvadesetak godina, statistička osnovica u Republici Hrvatskoj niti danas ne ispunjava nužne preduvjete potrebne za primjenu prognostičkih metoda koje zahtijevaju raspolaganje velikim brojem serija iz različitih sektora. Tako na primjer mnoge hrvatske serije karakterizira visoka razina šumova (odnosno iregularne komponente) koji onemogućavaju primjerenu primjenu statističkih metoda i bitno umanjuju robusnost dobivenih rezultata. Nadalje, mnogim hrvatskim serijama koje se u svijetu tradicionalno koriste za izračun navješćujućih indikatora se tijekom zadnjih petnaestak godina nekoliko puta mijenjala metodologija izračuna, a neke serije koje su uobičajene komponente navješćujućih indikatora (poput indeksa pouzdanja menadžera, izdanih građevinskih dozvola, indeksa narudžbi u industriji ili prinosa na državne obveznice) se ili ne objavljuju ili su se počele

objavljivati prije nekoliko godina, što nije dovoljno dugo razdoblje da bi se mogle koristiti za izračun navješćujućeg indeksa.

Ograničenjima usprkos, CROLEI sustav navješćujućih indikatora potrebno je kontinuirano metodološki usavršavati. U tu svrhu se u zadnjoj reviziji, čiji tijek je opisan u ovome članku, naglasak stavio na prelazak s nemodelskog na modelski pristup izradi CROLEI indeksa. Modelski pristup pretpostavlja da postoji direktna modelska veza između točaka zaokreta poslovnog ciklusa i komponenti navješćujućeg indeksa te između vrijednost CROLEI indeksa i projekcija kretanja poslovnog ciklusa. U ranijim revizijama CROLEI sustava nije bilo statističke poveznice između točaka zaokreta i komponenti CROLEI-a jer je metodologija izbora komponenti CROLEI indeksa bila modificirana u odnosu na originalnu NBER-ovu metodologiju. Modifikacija se odnosila na prva dva kriterija za komponente navješćujućeg indeksa (usuglašenost s poslovnim ciklusom i konzistentno prethođenje točkama zaokreta) koji su umjesto primjenom dva testa, testirani primjenom jednoga statističkoga testa – Grangerova testa uzročnosti. No budući da je Grangerov test uzročnosti prikladniji za testiranje usuglašenosti s poslovnim ciklusom, ali ne i za detekciju serija koje konzistentno prethode poslovnom ciklusu i točkama zaokreta, u ovoj reviziji je metodološka osnovica izmijenjena kako bi se uklonio navedeni nedostatak. Tako se konzistentno prethođenje točaka zaokreta testira logit modelom, čime se omogućuje direktna statistička (modelska) veza između točaka zaokreta i komponenti navješćujućeg indeksa. Logit model kao zavisnu varijablu koristi binarnu varijablu izračunatu primjenom transformacije izglađene vjerojatnosti ulaska u recesiju, varijable dobivene ocjenom Markovljevog modela na seriji indeksa volumena industrijske proizvodnje. Ispunjavanje kriterija usuglašenosti s poslovnim ciklusom se testira izračunom korelacijskih koeficijenata između potencijalnih komponenti i BDP-a, te ocjenom statističke značajnosti tih koeficijenata.

Novi CROLEI indeks sastoji se od osam komponenata: dvije komponente predstavljaju stanje ciklusa u najznačajnijim zemljama trgovinskim partnerima, a po jedna serija se odnosi na kretanja na tržištu kapitala, u proizvodnom, monetarnom i fiskalnom sektoru. Preostale dvije serije se odnose na uvoz kapitalne opreme i kretanje dohodaka u proizvodnom sektoru. U odnosu na CROLEI indeks izračunat na osnovi stare metodologije, novi CROLEI indeks uspješno navještava točke zaokreta poslovnog ciklusa. Također, dok stari CROLEI indeks navještava oporavak od kraja 2009. godine, vrijednost CROLEI indeksa izračunatog primjenom unaprijedene metodologije stagnira.

Na kraju valja naglasiti da postoji još mnogo prostora za metodološke inovacije u CROLEI sustavu navješćujućih pokazatelja. Moguće je daljnje unaprijediti izračun referentne serije na način da se vjerojatnost ulaska u recesiju računa na osnovi pratećeg (koincidirajućeg) indeksa, umjesto da se određuje na osnovi vrijednosti indeksa industrijske proizvodnje. Kombiniranje nekoliko serija u jed-

nu može se ostvariti determinističkim algoritmom sličnim onom koji se koristi za izračun CROLEI indeksa iz vrijednosti njegovih komponenti, ali bi se isto tako moglo ostvariti i ocjenom modela zajedničkih faktora na odabranim serijama. Nadalje, u sljedećim revizijama CROLEI indeksa treba težiti na prelazak na modelski pristup prognozama točaka zaokreta. U kontekstu nove CROLEI metodologije to bi značilo da se umjesto primjene determinističkog algoritma za izračun vrijednosti indeksa ocjenjuje logit model koji se sastoji od svih komponenti CROLEI indeksa odgovarajućeg vremenskog pomaka. Pomoću logit modela bi se zatim izrađivale projekcije vjerojatnosti ulaska u recesiju hrvatskog gospodarstva. Ta inovacija je bila iskušana i u reviziji opisanoj u ovom članku, ali nažalost još uvijek nije primjenjiva zbog premale varijabilnosti zavisne binarne varijable koja predstavlja dva stanja poslovnog ciklusa (recesiju i ekspanziju). No kako vrijeme bude prolazilo, i kako se s njim bude povećavao broj opažanja korištenih vremenskih serija, bit će moguće primijeniti i ovo metodološko unaprjeđenje CROLEI indeksa.

REFERENCE

- Ahec-Šonje, A. (1995.). "Metode predviđanja ekonomskih fluktuacija s naglaskom na "pristup indikatora", *Ekonomski pregled*, 46 (11-12): 820-837.
- Bačić, K., Vizek, M. (2006.). "A brand new CROLEI –Do we need a new forecasting index?", *Financijska teorija i praksa*, 30 (4): 311 – 346.
- Bačić, K., Vizek, M. (2008.). "Forecasting business and growth cycles in Croatia", *Ekonomski pregled*, 50 (11): 646 – 668.
- Bry, G., Boschan, C. (1971.). *Cyclical analysis of time series: Selected procedures and computer programs*, New York, National Bureau of Economic Research.
- Cerovac, S. (2005.). "Novi kompozitni indikatori za hrvatsko gospodarstvo: prilog razvoju domaćeg sustava cikličkih pokazatelja", *Istraživanja HNB*, I-16.
- Filardo, A. (1994.). "Business-cycle phases and their transitional dynamics", *Journal of Business and Economic statistics*, 12 (3): 299-308.
- Granger, C. W. J. (1969.). "Investigating Causal Relations by Econometric Methods and Cross-Spectral Methods", *Econometrica*, 34: 424-438.
- Hamilton, J. D. (1994.). *Time Series Analysis*, Princeton University Press, Princeton.
- Hamilton, J. D. (1989.). "A New Approach to the Economic Analysis of Nonstationary Time Series and the Business Cycle", *Econometrica*, 57: 357-384.
- Krolzig, H.M. (1997.). *Markov switching vector autoregressions. Modelling, statistical inference and application to business cycle analysis*, Springer, Berlin.

- Marcellino, M. (2006.) „Leading Indicators“, u Elliot, G, Granger, C. W. J., Timmermann, A. ur: *Handbook of Economic Forecasting*, Elsevier, Holland.
- Mitchell, W.C., Burns, A. F. (1938.). *Statistical Indicators of Cyclical Revivals*. New York: NBER.
- Moore, G.H., Shiskin, J. (1967.). *Indicators of Business Expansions and Contractions*, NBER, New York.
- Stock, J., Watson, M. (1989.). Probability model of the coincident indicators, *NBER working paper*, no. 2772.
- Šošić, I. (2006.). *Primijenjena statistika*, (2. izmijenjeno izdanje), Školska knjiga, Zagreb.
- Vizek, M. (2006.). "Ekonometrijska analiza kanala monetarnog prijenosa u Hrvatskoj", *Privredna kretanja i ekonomska politika*, 16 (109): 29-61.
- Wooldridge, J. (1999.). *Introductory Econometrics: a Modern Approach*, South Western Cengage Learning, USA.
- Zarnowitz, V., Boschan, C. (1975.). "Cyclical Indicators: An Evaluation and New Leading Indexes", in *Handbook of Cyclical Indicators*, U.S. Department of Commerce, BEA.
- Zarnowitz, V. (1992.). *Business Cycles: Theory, History, Indicators, and Forecasting*, The University of Chicago Press, za NBER, Chicago.

APPLICATION OF MODEL-BASED APPROACH TO THE CALCULATION OF THE LEADING COMPOSITE INDICATOR: THE CASE OF CROLEI INDEX

Summary

The aim of this paper is to improve the existing methodology of the construction of CROLEI index and to calculate new and improved CROLEI index. The purpose of CROLEI index is to signal the turning points in the business cycle in the Republic of Croatia and to provide information about future condition of the real economic activity. The methodological improvements correspond both to the selection of index components and to determination of past business cycle turning points. Business cycle turning points are determined using the filtered probabilities of entering into recession obtained by estimating the Markov switching model, while the selection of index components is based on correlation coefficients significance tests and logit model estimates. New CROLEI index is composed of eight series, and in terms of applied methodology and its ability to signal business cycle turning points it represents an improvement when compared to the old version of the index.

Key words: leading indicator, Markov switching model, logit model, Croatia